

Pemetaan Lamun Menggunakan Machine Learning Dengan Citra PlanetScope Di Nusa Lembongan

Devica Natalia Br Ginting^{1,2*} dan Sanjiwana Arjasakusuma¹

¹Departemen Sains Informasi Geografi, Fakultas Geografi, Universitas Gadjah Mada
Jl. Kaliurang, Sekip Utara, Bulaksumur, Yogyakarta 55281

²Pusat Pemanfaatan Penginderaan Jauh, Lembaga Penerbangan dan Antariksa Nasional
Jl. Kalisari No. 8, Pekayon Pasar Rebo, Jakarta 13710 Indonesia
Email: devicabr93@mail.ugm.ac.id

Abstract

Seagrass Mapping using Machine Learning from PlanetScope Imagery in Nusa Lembongan

Seagrass is one community in benthic habitat that has tremendous benefits for the ecosystem, however the existence of seagrass has been frequently marginalized in recent decades. Seagrass beds functions as a blue carbon ecosystem which are able to absorb carbon higher than terrestrial vegetation. Therefore, it is important to detect and map the seagrass beds distribution to calculate the potential carbon uptake from seagrass. The seagrass mapping can be employed efficiently by using remote sensing imagery and the use of machine learning technology. This research aims to examine the utilization of PlanetScope imagery (3.7 m spatial resolution) for seagrass mapping and to subsequently examine, the effect of atmospheric corrections, sun-glint, and the water column corrections on the accuracy of seagrass mapping. In addition, this study also identified the cover changes in seagrass area from 2016 to 2021 in Nusa Lembongan. The study utilized the tree-based machine learning methods such as decision tree and random forest. The results showed that the best model accuracy was generated by using raw PlanetScope data the best model accuracy of 98% and classification accuracy of 94% from decision tree method. Based on the decision tree mapping using PlanetScope data for 2016 and 2021, there was a decline in the seagrass cover from 100.53 hectares to 97.31 hectares.

Keyword: Seagrass, PlanetScope, Machine Learning, Nusa Lembongan

Abstrak

Lamun merupakan salah satu dari ekosistem habitat bentik yang memiliki manfaat yang sangat besar namun sebagai ekosistem, kehadiran lamun sering dikesampingkan beberapa dekade terakhir. Fungsi padang lamun sebagai ekosistem karbon biru mampu menyerap karbon lebih tinggi dibandingkan vegetasi daratan. Karena itu, penting untuk mendeteksi dan memetakan informasi padang lamun untuk memperhitungkan serapan karbon oleh lamun. Pemanfaatan lamun dapat dilakukan secara cepat dan efisien dengan menggunakan teknologi penginderaan jauh dan pemanfaatan teknologi *machine learning*. Penelitian bertujuan untuk mengkaji pemanfaatan citra PlanetScope untuk memetakan lamun dan selanjutnya menganalisis pengaruh kalibrasi atmosferik, *sun-glint*, dan kolom air terhadap akurasi pemetaan padang lamun. Selain itu, perubahan tutupan lamun tahun 2016 – 2021 di Nusa Lembongan juga dipetakan. Penelitian ini menggunakan metode *machine learning* berbasis pohon seperti *decision tree* dan *random forest*. Hasil penelitian menunjukkan akurasi model terbaik dihasilkan dengan menggunakan data mentah dengan akurasi model 98% dan akurasi klasifikasi 94% dari metode *decision tree*. Berdasarkan data PlanetScope tahun 2016 dan 2021 dengan menggunakan metode *decision tree* terjadi penurunan luasan lamun dari 100,53 Ha menjadi 97,31 Ha.

Kata kunci: Lamun, PlanetScope, Machine Learning, Nusa Lembongan

PENDAHULUAN

Indonesia memiliki kekayaan sumber daya laut yang melimpah dan perlu dikelola dengan baik, salah satunya adalah lamun. Indonesia merupakan negara dengan padang lamun terluas di Asia Tenggara dan kedua di dunia sekitar 150.693,16 ha (Badan Informasi Geospasial, 2012) serta dengan keragaman yang besar yaitu 15 spesies dari 60 spesies lamun di dunia (Sjafrie *et al.*, 2018). Ekosistem lamun memiliki manfaat yang sangat besar antara lain: sebagai pelindung pantai, produsen primer, habitat bagi biota laut, dan penyimpan karbon (Sjafrie *et al.*, 2018, Duarte *et al.*, 2013). Lamun sebagai ekosistem karbon biru mampu menyimpan CO₂ pada tubuh dan sedimennya lebih banyak dibandingkan vegetasi daratan (McLeod *et al.*, 2011). Selain itu, lamun juga mampu menyimpan karbon dalam waktu yang lama karena kondisi substrat yang mengandung air menyebabkan sulitnya terjadi pelepasan karbon (Howard *et al.*, 2014). Oleh sebab itu, padang lamun memiliki potensi yang sangat besar dalam penyerapan karbon dan mitigasi perubahan iklim.

Potensi yang besar pada padang lamun belum didukung dengan pengelolaan yang baik. Pembangunan yang masif dan aktivitas yang tinggi di pesisir menyebabkan padang lamun rentan terhadap ancaman kerusakan. Selain itu, perubahan kondisi lingkungan juga mempengaruhi pertumbuhan yang berdampak pada perubahan luasan lamun. Berdasarkan penelitian yang dilakukan oleh Duarte *et al.* (2008) terjadi pengurangan luasan lamun dunia rata-rata 2 - 5% setiap tahun. Selain pengurangan luasan, berdasarkan penelitian P2O-LIPI melalui proyek COREMAP-CTI selama kurun waktu 2015-2017, padang lamun Indonesia termasuk dalam kondisi kurang sehat (Sjafrie *et al.*, 2018). Kondisi ini menunjukkan perlunya tindakan cepat dan tepat dari instansi terkait untuk berkolaborasi dalam memantau dan mengelola padang lamun di Indonesia.

Pemanfaatan teknologi penginderaan jauh dapat digunakan untuk pemetaan dan pemantauan padang lamun secara efektif dan efisien karena mampu menghasilkan

informasi secara spasial dan temporal. Data penginderaan jauh mampu mendukung dalam menyediakan informasi luasan, persen tutupan, spesies, biomasa, dan perubahan lamun. Penelitian mengenai pemanfaatan citra penginderaan jauh untuk ekstraksi padang lamun menggunakan metode *maximum likelihood classification* mampu menghasilkan akurasi diatas 60 % (citra multispektral) dan diatas 70% (hyperspektral) baik pada sebaran spesies maupun persen tutupan dimana citra dengan resolusi spasial lebih tinggi menghasilkan akurasi yang lebih baik (Fauzan *et al.*, 2017; Koedsin *et al.*, 2016). Pemanfaatan metode *maximum likelihood classification* baik digunakan ketika menggunakan citra resolusi spasial tinggi namun proses pengolahan yang lebih cepat dan akurasi yang lebih baik dapat dihasilkan dengan menggunakan *machine learning* yang sedang berkembang setara dengan perkembangan teknologi (Zhang dan Xie, 2012; Zhang *et al.*, 2013). Proses klasifikasi dengan *machine learning* menggunakan *tree-based learning* seperti *decision tree* dan *random forests* saat ini menjadi lumrah untuk digunakan dengan akurasi yang baik dan beban komputasi yang lebih ringan (Chan dan Paelinckx, 2008)

Proses pemetaan menggunakan data penginderaan jauh membutuhkan proses pra-pemrosesan data untuk menghilangkan gangguan eksternal pada data. Pada analisis pemetaan habitat bentik diperlukan beberapa koreksi citra, antara lain koreksi atmosferik, *sun-glint*, dan kolom air akan dianalisis untuk memahami prosedur pemetaan padang lamun. Penelitian Zhang *et al.* (2013) menunjukkan bahwa ketiga koreksi ini tidak diperlukan pada pemetaan habitat bentik di Florida keys. Hal ini dikarenakan proses segmentasi pada klasifikasi berbasis objek yang meminimalisir pengaruh *sun-glint* serta dasar perairan daerah kajian yang homogen yang tidak sesuai dengan metode koreksi kolom air yang digunakan (Lyzenga, 1981). Hal berbeda ditunjukkan oleh penelitian Tamondong *et al.* (2013) dimana citra Worldview-2 yang sudah dikoreksi kolom air dan dilakukan proses *pricipal component analisis* menghasilkan akurasi terbaik. Inkonsistensi dalam koreksi citra ini memerlukan kajian lebih lanjut untuk

melihat level koreksi yang diperlukan dalam proses pemetaan seagrass.

Tujuan penelitian ini adalah untuk mengkaji pemetaan padang lamun dengan menggunakan *machine learning*. Selain itu, berbagai data input yang diberikan dianalisis untuk mengetahui pengaruh kalibrasi citra pada pemetaan padang lamun seperti koreksi atmosferik, sun-glint, dan kolom air. Analisis perubahan luasan lamun untuk mengetahui kondisi dinamis dari lamun di daerah kajian. Nusa Lembongan dipilih sebagai daerah kajian karena masih belum updatenya informasi terkait luasan lamun dan terjadi perubahan signifikan terhadap luasan lamun yang dapat dilihat secara visual di Nusa Lembongan.

MATERI DAN METODE

Nusa lembongan merupakan salah satu pulau di Kabupaten Klungkung Bali yang kaya akan padang lamun (Gambar 1). Berdasarkan survey yang dilakukan Coral Triangle Center bersama Universitas Udayana, luasan padang lamun di daerah kajian adalah 108 hektar dengan delapan jenis spesies lamun yaitu *Thalassia hemprichii*, *Halophila decipiens*, *Halophila ovalis*, *Enhalus acoroides*, *Cymodocea rotundata*, *Syringodium isoetifolium*, *Cymodocea serrulata*, dan *Halodule uninervis* (Kabupaten


Klungkung, 2012). Nusa Lembongan juga merupakan salah satu tempat wisata domestik maupun mancanegara. Peningkatan minat wisatawan menyebabkan banyak warga sekitar daerah yang mengganti sumber mata pencaharian dari pembudidaya rumput laut menjadi pariwisata (Badan Pusat Statistik Indonesia, 2018). Peningkatan aktivitas pariwisata menambah tingkat kerentanan terhadap lamun. Gambar 2 merupakan gambaran umum perubahan luasan lamun di daerah kajian dari tahun 2009–2020.

Citra PlanetScope yang diakusisi pada dua tanggal digunakan pada penelitian ini untuk melihat perubahan tutupan lamun di daerah kajian. Level produk yang digunakan adalah PlanetScope 3B yang sudah melalui proses ortoretifikasi dan nilai piksel merupakan *Top-of-Atmosphere (TOA) radiance* (Planet, 2017). Kedua data diakusisi pada tanggal 28 Agustus 2016 dan 07 Februari 2021. Kedua perekaman data dalam kondisi tidak ada awan yang menutupi (bebas awan). Resolusi dari data PlanetScope (Tabel 1).


Untuk menghitung akurasi, 100 titik didistribusikan secara acak di habitat lamun dan non-lamun dengan sebaran seimbang yaitu 50 banding 50. Sebaran titik validasi dapat dilihat pada Gambar 3.



Gambar 1. Nusa Lembongan (Citra PlanetScope diakusisi 07 Februari 2021)



Gambar 2. Perubahan luasan lamun dari tahun 2009 – 2020 (Google earth pro)



Gambar 3. Titik validasi untuk uji akurasi (warna merah untuk lamun dan warna hijau untuk non lamun)

Citra melalui proses masking darat. Selanjutnya dikoreksi atmosferik, *sun-glint*, dan kolom air. Data input untuk proses klasifikasi adalah empat data berupa data yang sudah dimasking (mentah), hasil koreksi atmosferik, *sun-glint*, dan kolom air. Untuk melihat data input terbaik, keempat hasil klasifikasi tersebut melalui proses uji akurasi. Model dengan hasil akurasi terbaik selanjutnya digunakan untuk menganalisis perubahan luasan lamun.

Objek darat pada daerah kajian akan dimasking karena objek yang akan dianalisis adalah lamun. Penghapusan objek darat dilakukan untuk proses pengolahan yang lebih efisien. Selain itu, objek lamun di daerah kajian berada bersebelahan dengan objek mangrove dan pengaruh pasang surut. Masking darat menggunakan metode perbandingan rasio Green dan NIR serta klasifikasi visual. Berdasarkan penelitian Ginting dan Faristyawan (2020), metode tersebut mampu memisahkan wilayah garis pantai bervegetasi dengan non-vegetasi. Klasifikasi visual dilakukan untuk memastikan hasil masking darat.

TOA reflektan diperoleh dengan mengalikan nilai piksel dengan koefisien reflektan (Tabel 2) yang dapat diperoleh di metadata. Untuk memperoleh reflektan dibawah permukaan air digunakan metode *Dark-Object Subtraction* (DOS) dengan menggunakan piksel pada perairan dalam.

Metode koreksi *sun-glint* yang digunakan adalah metode (Hedley *et al.*, 2005). Metode

ini dibangun berdasarkan hubungan linier antara NIR dan band tampak pada area latih. Berdasarkan penelitian Hochberg *et al.* (2003), area latih yang dipilih merupakan satu atau lebih piksel dengan *sun-glint* tetapi dengan kecerahan spektral yang konsisten (perairan dalam).

$$R_i' = R_i - b_i(R_{NIR} - Min_{NIR})$$

Keterangan : R_i = Band yang ingin dikoreksi; b_i = Slope dari regresi linear; R_{NIR} = Band NIR; Min_{NIR} = Nilai Minimum area tanpa *sun-glint*; R_i' = Band terkoreksi

Pemetakan habitat dasar perairan laut dangkal menggunakan citra satelit sangat dipengaruhi oleh kondisi atmosfer dan kolom air (Mumby *et al.*, 1998). Radiasi yang dipancarkan oleh sensor melalui atmosfer dan kolom air akan dipantulkan oleh objek dasar dan direkam kembali oleh sensor. Koreksi atmosfer dan kolom air diperlukan untuk menentukan pantulan dasar perairan. Lyzenga (1978) menggunakan dua kanal dalam formulasi untuk melakukan koreksi kolom air. Algoritma Lyzenga (1978) adalah sebagai berikut:

$$Y = \ln(L_i) - \left[\left(\frac{k_i}{k_j}\right) \times \ln(L_j)\right]$$

Keterangan : Y = indeks kedalaman invariant; L_i = mewakili nilai spektral dalam band i ; L_j = menunjukkan nilai spektral dari band j ; k_i / k_j = koefisien atenuasi air pada pita i dan j

Tabel 1. Resolusi data PlanetScope

Band	Spektral	Temporal	Radiometrik	Spasial
Blue	455 - 515	1 hari	16 bit	3 m
Green	500 - 590			
Red	590 - 670			
NIR	780 - 860			

Tabel 2. Koefisien reflektan

Band	28 Agustus 2016	07 Februari 2021
Blue	2,2371851 x 10 ⁻⁵	1,7573427 x 10 ⁻⁵
Green	2,3893295 x 10 ⁻⁵	1,9059747 x 10 ⁻⁵
Red	2,6718246 x 10 ⁻⁵	2,2941037 x 10 ⁻⁵

NIR	4,1584574 x 10 ⁻⁵	3,6309893 x 10 ⁻⁵
-----	------------------------------	------------------------------

Model klasifikasi dibangun berdasarkan nilai band biru, hijau, dan merah dari training area dengan menggunakan software R. Metode yang digunakan adalah *Decision tree* dan *Random forest* yang merupakan sistem klasifikasi terselia dengan menggunakan *machine learning*. Untuk *decision tree* digunakan fungsi *c50* sedangkan pada *random forest* menggunakan fungsi *randomForest* (Core Team R, 2016). Model yang dihasilkan selanjutnya digunakan untuk melakukan klasifikasi kelas lamun dan non-lamun pada citra sehingga dapat dihasilkan informasi luasan lamun di daerah kajian.

Matriks kesalahan digunakan untuk melakukan uji akurasi dengan tiga kategori pada matriks konfusi yaitu akurasi produsen (PA), akurasi pengguna (UA), dan akurasi keseluruhan (OA). Akurasi keseluruhan (OA) merupakan persentasi dari sample yang terklasifikasi dengan benar dari total sample, sedangkan akurasi produsen (PA) menunjukkan persentasi tingkat kebenaran data sampel lapangan akan terklasifikasikan dengan benar pada citra, sedangkan akurasi pengguna (UA) menunjukkan persentasi kemungkinan dari pengguna peta akan menemukan informasi yang benar di lapangan. Apabila nilai akurasi produser lebih kecil dibandingkan dengan akurasi pengguna pada suatu kelas maka, kelas tersebut cenderung *overestimate*, jika sebaliknya maka cenderung *underestimate*.

HASIL DAN PEMBAHASAN

Data yang digunakan untuk membangun model merupakan data mentah, data yang sudah dikoreksi radiometrik, *sunglint*, dan kolom air. Hasil model yang dibangun menunjukkan bahwa dengan menggunakan kedua metode, hasil dengan akurasi terbaik ditunjukkan oleh model yang dibangun menggunakan data mentah. Berdasarkan akurasi model yang diperoleh untuk membangun model dengan menggunakan metode *machine learning* pada data PlanetScope dapat digunakan data mentah tanpa melalui proses kalibrasi (Tabel 3). Akurasi model yang baik pada data mentah disebabkan oleh kondisi citra yang

bersih dan bebas awan. Hasil penelitian ini menunjukkan hasil yang sama dengan penelitian yang dilakukan oleh Zhang *et al.* (2013) yang menganalisis pengaruh kalibrasi pada data AVIRIS dengan menggunakan metode GEOBIA dan *Random forest*.

Tabel 3. Akurasi model dalam (%)

Data	Random Forest	Decision Tree
Mentah	98	98
Radiometrik	76	77
Sunglint	79	84
Kolom air	76	81

Hasil uji akurasi hasil klasifikasi dengan akurasi model menunjukkan hasil yang sama yaitu akurasi terbaik ditunjukkan oleh data mentah dengan akurasi keseluruhan diatas 90% (Tabel 4). Perbandingan dari kedua metode yang digunakan menunjukkan bahwa metode *Decision tree* menunjukkan hasil uji akurasi terbaik. Penelitian yang dilakukan oleh Effrosynidis *et al.* (2018) membandingkan metode *supervised machine learning* untuk mendeteksi lamun dan menunjukkan bahwa metode berbasis pohon yaitu *Decision tree* dan *Random forest* menunjukkan akurasi terbaik.

Hasil klasifikasi dengan menggunakan metode *Random forest* dan *Decision tree* menunjukkan hasil yang tidak terlalu berbeda secara spasial (Gambar 5). Namun berdasarkan perbandingan akurasi pengguna dan produser, metode *Random Forest* untuk input data mentah menunjukkan misklasifikasi pada objek lamun yang ditandai dengan akurasi pengguna yang lebih rendah dibandingkan akurasi produser. Kesalahan klasifikasi terjadi di daerah transisi antara perairan dangkal dengan dalam, ombak dan badan kapal yang ditandai sebagai lamun.


Luasan lamun pada tahun 2021 diperoleh melalui model yang dibangun dengan menggunakan data tahun 2016. Hasil klasifikasi luasan lamun selanjutnya dilakukan *manual editing* dengan mengidentifikasi kesalahan klasifikasi dan mengedit simpul

vektor yang tidak mewakili lamun. Tindakan ini dilakukan untuk memastikan bahwa tutupan lamun sudah mencerminkan kondisi lamun

dengan akurat sehingga dapat digunakan untuk menganalisis perubahan luasan lamun.

Tabel 4. Uji akurasi

		Mentah					
Kelas		Random Forest			Decision Tree		
		UA	PA	OA	UA	PA	OA
Lamun		86	98	91	94	94	94
Non-lamun		97	84		94	94	
		Kalibrasi Radiometrik					
Kelas		Random Forest			Decision Tree		
		UA	PA	OA	UA	PA	OA
Lamun		77	54	69	81	68	76
Non-lamun		65	84		84	84	
		Sunglint					
Kelas		Random Forest			Decision Tree		
		UA	PA	OA	UA	PA	OA
Lamun		77	54	69	77	84	80
Non-lamun		65	84		82	76	
		Kolom air					
Kelas		Random Forest			Decision Tree		
		UA	PA	OA	UA	PA	OA
Lamun		73	56	68	80	72	77
Non-lamun		65	80		74	83	



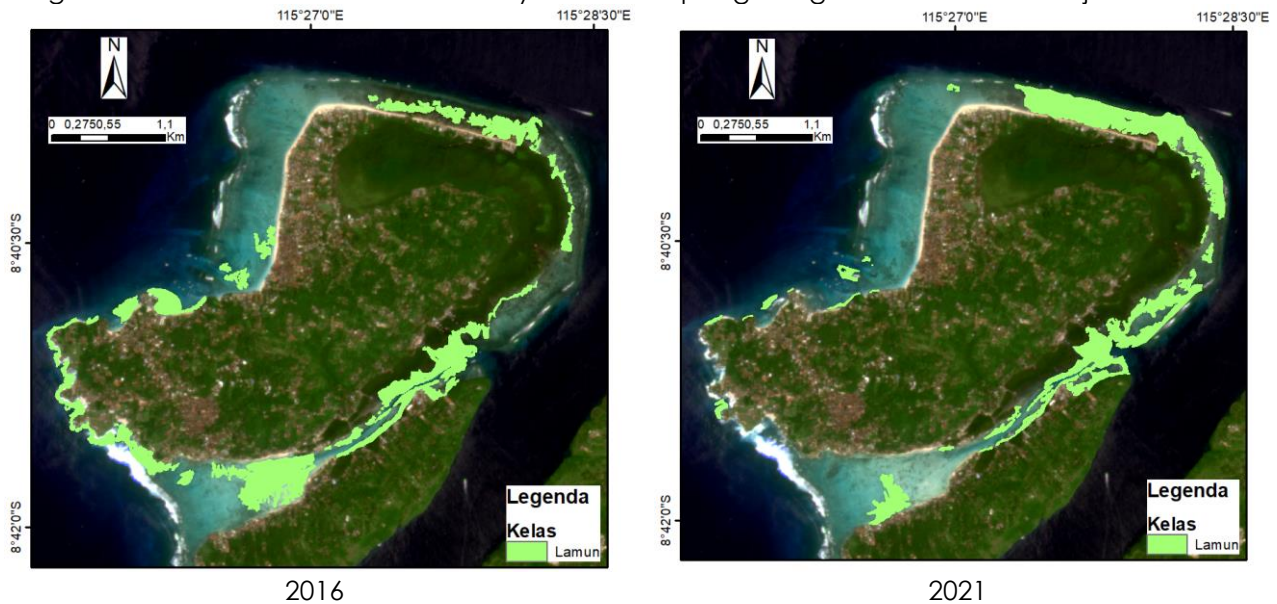
Gambar 5. Klasifikasi lamun Tahun 2016 dengan menggunakan metode a. *Random forest* dan b. *Decision tree* (polygon hijau pada gambar menunjukkan objek lamun)

Besaran luasan lamun pada tahun 2016 dan 2021 adalah 100,53 Ha menjadi 97,31 Ha.

Luasan lamun turun sekitar 3,19 Ha. Jika dibandingkan dengan data yang

disampaikan oleh Kabupaten Klungkung pada Tahun 2012 yang merupakan hasil kerjasama survey yang dilakukan antara Coral Triangle Center bersama Universitas Udayana

terjadi penurunan luasan Lamun sekitar 7,5 Ha dari Tahun 2010 – 2016 (Kabupaten Klungkung, 2012). Pada Gambar 6 dapat dilihat pengurangan luasan lamun terjadi di selatan



Gambar 6. Luasan lamun dengan menggunakan metode *Decision tree* (polygon hijau pada gambar menunjukkan objek lamun)

dan barat Nusa Lembongan. Wilayah selatan merupakan wilayah pertemuan air dari Samudera India dengan perairan di Nusa Lembongan. Kondisi pengurangan lamun yang terjadi wilayah ini sangat dimungkinkan akibat dari kondisi fisis perairan yang berubah antara suhu muka laut (Nuryana *et al.*, 2018). Analisis lebih lanjut diperlukan untuk mengetahui penyebab penurunan luasan lamun seperti overlay dengan informasi fisis dari perairan di daerah kajian. Selain penurunan luasan lamun, penambahan luasan lamun juga terjadi dan dapat dilihat terjadi pada bagian utara wilayah kajian dengan dinamika kondisi fisis perairan lebih stabil.

KESIMPULAN

Penelitian ini menunjukkan bahwa akurasi model dan uji akurasi pada pemetaan lamun dengan menggunakan citra PlanetScope dan *machine learning* menunjukkan akurasi baik sehingga dapat digunakan untuk pemetaan lamun dengan lebih efektif dan efisien. Pemetaan padang lamun pada data PlanetScope dengan

menggunakan *machine learning* menunjukkan input data berupa data mentah menunjukkan akurasi terbaik dan koreksi atmosferik, *sunglint*, kolom air tidak memberikan dampak pada akurasi pemetaan lamun. Model yang dihasilkan dengan menggunakan metode *machine learning* dapat digunakan untuk menghasilkan peta lamun pada data lainnya. Analisis luasan lamun pada tahun 2016 dan 2021 menunjukkan terdapat perubahan yang signifikan terhadap padang lamun di Nusa Lembongan.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada *PlanetScope for Education and Research Program* untuk data yang digunakan pada penelitian ini. Penulis juga mengucapkan terima kasih kepada Pusat Pemanfaatan Penginderaan Jauh, LAPAN dan Kemenristek/BRIN yang sudah mendukung penelitian ini.

DAFTAR PUSTAKA

- Badan Informasi Geospasial. 2012. *Informasi geospasial mangrove Indonesia*. Bogor: Pusat Pemetaan dan Informasi Tematik; Badan Informasi Geospasial Indonesia; 335pp.
- Badan Pusat Statistik Indonesia. 2018. *Statistik Sumber Daya Laut dan Pesisir 2018*. 1–335.
- Chan, J.C.W., & Paelinckx, D. 2008. Evaluation of Random Forest and Adaboost tree-based ensemble classification and spectral band selection for ecotope mapping using airborne hyperspectral imagery. *Remote Sensing of Environment*, 112(6):2999-3011.
- Core Team R. 2016. A Language and Environment for Statistical Computing; R Foundation for Statistical Computing. <https://www.R-project.org/>, Vienna, Austria.
- Duarte, C.M., Tomas, S. & Marba, N. 2013. Assessing the CO₂ capture potential of seagrass restoration projects. *Journal of Applied Ecology*, 50:1341–1349. doi: 10.1111/13652664.12155.
- Duarte, C.M., Dennison, W.C., Orth, R.J. & Carruthers, T.J. 2008. The Charisma of Coastal Ecosystems: Addressing the Imbalance. *Estuaries and Coasts*, 31(2):233–238. doi: 10.1007/S12237-008-9038-7.
- Effrosynidis, D., Arampatzis, A. & Sylaios, G. 2018. Seagrass detection in the Mediterranean: A supervised learning approach. *Ecological Informatics*, 48: 158–170.
- Fauzan, M.A., Kumara, I.S.W., Yogyantoro, R., Suwardana, S., Fadhilah, N., Nurmallasari, I., Apriyani, S. & Wicaksono, P. 2017. Assessing the Capability of Sentinel-2A Data for Mapping Seagrass Percent Cover in Jerowaru, East Lombok. *Indonesian Journal of Geography*, 49(2): 195 - 203.
- Ginting, D.N.B. & Faristyawan, R. 2020. Deteksi Tipe dan Perubahan Garis Pantai Menggunakan Analisis Digital Citra Penginderaan Jauh. *Geomatika*, 6(1): 17–24. doi : 10.24895/jig.2020.26-1.977.
- Hedley, J.D., Harborne, A.R., & Mumby, P.J. 2005. Simple and robust removal of sun glint for mapping shallow-water benthos. *International Journal of Remote Sensing*, 26(10):2107–2112. doi: 10.1080/01431160500034086
- Hochberg, E.J., Andréfouët, S. & Tyler, M.R. 2003. Sea surface correction of high spatial resolution ikonos images to improve bottom mapping in near-shore environments. *IEEE Transactions on Geoscience and Remote Sensing*, 41(7 PART II):1724–1729. doi: 10.1109/TGRS.2003.815408
- Howard, J., Hoyt, S., Isensee, K., Pidgeon, E., & Telszewski, M. 2014. Coastal Blue Carbon: Methods for Assessing Carbon Stocks and Emissions Factors in Mangroves, Tidal Salt Marshes, and Seagrass Meadows. Arlington, Virginia, USA: Conservation International, Intergovernmental Oceanographic Commission of UNESCO, International Union for Conservation of Nature.
- Kabupaten Klungkung. 2012. Rencana Pengelolaan KKP Nusa Penida. Kabupaten Klungkung, Propinsi Bali.
- Koedsin, W., Intararuang, W., Ritchie, R.J. & Huete, A. 2016. An integrated field and remote sensing method for mapping seagrass species, cover, and biomass in Southern Thailand. *Remote Sensing*, 8(4):p.292. doi: 10.3390/rs8040292
- Lyzenga, D.R. 1978. Passive remote sensing techniques for mapping water depth and bottom features. *Applied Optics*, 17(3):379-383. doi : 10.1364/ao.17.000379
- Lyzenga, D.R. 1981. Remote sensing of bottom reflectance and water attenuation parameters in shallow water using aircraft and landsat data. *International Journal of Remote Sensing*, 2(1):71–82. doi : 10.1080/01431168108948342
- Mcleod, E., Chmura, G.L., Bouillon, S., Salm, Rodney., Bjork, M., Duarte, C. M., Lovelock, C.E., Schlesinger, W.H. & Silliman, B.R. 2011. A Blueprint For Blue Carbon: Toward an Improved Understanding of The Role Of Vegetated Coastal Habitats in Sequestering CO₂. *Frontiers in Ecology and the Environment*, 9:552-260.
- Mumby, P.J., Clark, C.D., Green, E.P., & Edwards, A.J. 1998. Benefits of water column correction and contextual editing for mapping coral reefs.

International Journal of Remote Sensing, 19(1):203–210. doi: 10.1080/014311698216521

- Nuryana, J., Hendrawan, I.G. & Karim, W. 2018. Pendugaan Kejadian Pemutihan Karang Berdasarkan Analisis Suhu Permukaan Laut (SPL) Tahun 2015-2016 di Perairan Bali. *Journal of Marine and Aquatic Sciences*, 4(2):286-296
- Planet. 2017. Planet Imagery Product Specification. San Francisco, CA: Planet Labs Emisi Gas Rumah Kaca.
- Sjafrie, N.D.M., Hernawan, U.E., Prayudha, B., Supriyadi, I.H., Iswari, M.Y., Rahmat., Anggaraini, K. & Rahmawati, S.S. 2018. Status Padang Lamun Indonesia. *P2OLIP*.
- Tamondong, A.M. Blanco, A.C. Fortes, M.D. & Nadaoka, K. 2013. Mapping of seagrass and other benthic habitats in Bolinao,

Pangasinan using Worldview-2 satellite image. In *Proceedings of the IGARSS 2013—2013 IEEE International Geoscience and Remote Sensing Symposium, Melbourne, VIC, Australia*, 21:1579–1582. doi: 10.1109/IGARSS.2013.6723091.

- Zhang, C. & Xie, Z. 2012. Combining object-based texture measures with a neural network for vegetation mapping in the Everglades from hyperspectral imagery. *Remote Sensing of Environment*, 124: 310e320.
- Zhang, C., Selch, D., Xie, Z., Roberts, C., Cooper, H., & Chen, G. 2013. Object-Based Benthic Habitat Mapping In The Florida Keys From hyperspectral Imagery. *Estuarine, Coastal and Shelf Science*, 134: 88e97.